

# 基于 EEMD 去噪和集对理论的风功率实时预测研究

杨 茂<sup>1</sup>, 陈郁林<sup>1</sup>, 魏治成<sup>2</sup>

(1. 东北电力大学电气工程学院, 吉林 132012; 2. 国网安徽省电力公司检修公司, 合肥 230061)

**摘 要:** 提出一种基于整体平均经验模态分解(EEMD)去噪和改进秩次集对分析的风电功率实时预测模型。首先利用EEMD将风电功率时间序列进行分解,得到有限个本征模态分量(IMF)和一个趋势分量;然后将高频IMF分量中与原始序列相关性较小的分量作为噪声滤除,将余下的分量进行重构得到消噪序列;最后利用秩次集对分析法对消噪序列进行预测。在建立秩次集对分析预测模型时,考虑风电功率幅值在建立联系度中的作用,改进联系度的建立过程。采用3个不同装机容量的风电场的实测风电功率数据进行仿真实验,结果表明:该文所提出的预测模型具有优越的预测性能,并显示出良好的普适性。

**关键词:** 风电功率; 实时预测; EEMD去噪; 秩次集对分析; 联系度

**中图分类号:** TM614

**文献标识码:** A

## 0 引 言

风电是目前技术最为成熟、最具发展前景的新能源。但是,风电本身固有的非平稳性、随机性和不确定性削弱了含风电的电力系统对电能的可控性,同时也给大规模风电并网后电力系统的安全稳定运行带来了很多问题,制约了风电的进一步发展<sup>[1-3]</sup>。虽然目前也有一些方法能够解决这些问题,但大部分方法牺牲了系统运行的经济性,如加装系统备用容量等。而对风速或风电功率进行准确预测不但能在很大程度上解决风电固有特性带来的问题,而且保证了经济性。

目前,风电功率预测按方法分类大致可分为基于数值天气预报(NWP)、地理条件以及环境因素等的物理方法<sup>[4,5]</sup>和基于历史数据的统计方法,它们各有优劣。物理方法对预测时间范围较长的中期预测(6~24 h)和长期预测(1~7 d)的预测效果较好,而统计方法则对短期预测(6 h以内)更具优越性。但由于准确的数值天气预报很难获得,因此目前统计方法在风电功率中的应用更广泛。常用的统计方法有持续法<sup>[6]</sup>、时间序列法<sup>[7]</sup>、人工神经网络法<sup>[8]</sup>、支持向量机法<sup>[9-11]</sup>以及这些方法的组合方法等。

实时预测是国家能源局文件<sup>[12]</sup>风电场功率预测预报管理暂行办法中规定的一种对未来15分钟至4小时的风电功率进行时间分辨率为15 min的预测预报。对风电功率进行准确的实时预测,能够为电网调度控制和运行方式的制定提供可靠的支持,从而降低风电功率特性对电网的不利影响,增强电力系统对电能的控制力。实时预测属于超短期风电功率预测范畴,因此更适合用统计方法。目前大部分风电功率预测方法未考虑风电功率数据在采集过程中受到各种因素干扰而产生的噪声的影响,使预测方法的预测性能受到限制。

本文提出一种基于整体平均经验模态分解(EEMD)去噪和改进秩次集对分析的风电功率实时预测方法。首先,利用EEMD方法对风电功率时间序列进行去噪处理;然后利用改进秩次集对分析方法对去噪后的EEMD分量进行预测;最后将得到的各个分量的预测值进行重构,作为预测值。并利用多个不同装机容量的风电场出力数据进行仿真,仿真结果表明:本文提出的基于EEMD和改进秩次集对分析的风电功率实时预测模型具有优越的预测性能,而且对于不同装机容量的风电功率序列具有良好的普适性。

收稿日期: 2016-03-15

基金项目: 国家重点基础研究发展(973)计划(2013CB228201); 国家自然科学基金(51307017); 吉林省科技发展计划(20140520129JH); 吉林省产业技术与专项开发项目(2014Y124)

通信作者: 杨 茂(1982—), 男, 博士、副教授, 主要从事风力发电技术方面的研究。yangmao820@163.com

## 1 方法原理

### 1.1 整体平均经验模态分解(EEMD)

经验模态分解(empirical mode decomposition, EMD)是一种基于信号自身尺度的,较新的处理非稳定、非线性信号的方法。因此,其适用于分析具有较强随机性和波动性的风电功率时间序列。它与小波分解、傅里叶变换等方法相比,无需设定基函数、分解层数和阈值等参数,具有直观和自适应等优点,而且它是一个有限次滤波的过程<sup>[13]</sup>。

EMD方法具有很好的自适应性,所以其在处理非线性和非平稳信号上得到成功应用。但EMD方法仍存在问题,即模态混叠现象。当信号出现中断或信号的时间尺度出现跳跃性变化时,就会出现该现象,致使IMF分量失去其物理意义。

模态混叠现象的表现为:

1)同一个IMF分量中包含时间尺度差异较大的局部信号分量;

2)同一时间尺度的局部信号分量出现在不同的IMF分量中。

模态混叠现象会使EMD分解得到的IMF分量中包含其他本征模态分量,因此在去噪过程中,滤除的高频分量中会含有其他频带有用信息,使得去噪效果降低。

基于EMD的模态混叠现象,Wu等<sup>[1]</sup>提出整体平均经验模态分解方法(ensemble empirical decomposition, EEMD)<sup>[13]</sup>。EEMD是一种利用噪声数据的方法,将不同的白噪声信号多次添加到被分解的信号中,再对添加了白噪声的信号进行EMD分解,将多次分解得到的同频带的IMF分量求平均作为最终的IMF分量。这种经过整体平均后得到的IMF分量可自动消除模态混叠问题。

EEMD整体的分解和EMD分解的步骤大致相同,只是在确定IMF分量时进行了加噪处理,其具体过程如下:

1)将待分解信号 $x(t)$ 多次加入等长度的白噪声信号 $n_n(t)$ ,得到加噪信号 $x_n(t)$ :

$$x_n(t) = x(t) + k \times n_n(t) \quad (1)$$

式中, $k$ ——幅值系数。

2)按EMD分解步骤将 $x_n(t)$ 进行 $n$ 次EMD分

解,得到IMF分量 $c_{n,i}(t)(i=1,2,L,m)$ , $c_{n,i}(t)$ 为第 $n$ 次加入白噪声后分解得到的第 $i$ 个IMF分量。

3)根据不相关随机序列统计均值为零的原理,对 $c_{n,i}(t)$ 进行整体平均,使得多次加入的白噪声对IMF的影响相互抵消,则最终得到的第 $i$ 个IMF分量为:

$$c_i(t) = \frac{1}{N} \sum_{n=1}^N c_{n,i}(t) \quad (2)$$

白噪声的幅度 $\varepsilon$ 和整体平均次数 $n$ 满足统计规律:

$$\varepsilon_n = \varepsilon / \sqrt{n} \quad (3)$$

或:

$$\ln \varepsilon_n + \frac{\varepsilon}{2} \ln(n) = 0 \quad (4)$$

其中, $\varepsilon_n$ 为原始信号与经EEMD分解后的IMF分量又重构为新的信号之间的误差。从式(3)或式(4)中可知,整体平均次数 $n$ 越大, $\varepsilon_n$ 越小,即白噪声的影响越小,经EEMD分解后又重构的信号越保真。所以EEMD的本质是利用白噪声频谱均衡分布的统计特征,使得加入白噪声的信号在不同时间尺度上具有连续性,从而改变了信号极值点的特征,最后整体平均过程又使其中的白噪声相互抵消,保留了信号的真实面貌。

### 1.2 秩次集对分析

集对分析(set pair analysis, SPA)<sup>[14]</sup>是一种较新颖的确定和不确定性问题分析方法。它建立在自然辩证法中事物普遍联系和对立统一的思想之上,其思想来源于系统成对理论,理论基础扎实。它是通过建立客观事物属性之间的联系度来刻画事物之间的确定和不确定性关系的,SPA具体分析方法为:首先建立集对,即具有一定联系的两个集合组成的对子,如集合 $A$ 和集合 $B$ 构成集对 $H(A,B)$ ;然后按照一定的规则对两集合的属性进行同、异、反分析,得到由同一度、差异度和对立度构成的联系度,其表达式如下:

$$\mu(A, B) = \frac{S}{N} + \frac{F}{N}i + \frac{P}{N}j \quad (5)$$

式中, $\mu(A, B)$ ——集对 $H$ 的联系度; $N$ ——集对特性总数; $S$ ——集合 $A$ 和 $B$ 中共同特性的个数,则 $\frac{S}{N}$ 为同一度; $P$ ——对立特性的个数,则 $\frac{P}{N}$ 为对立度; $F$ ——既非共同也非对立的特性的个数,则为

$\frac{F}{N}$  差异度, 即有  $N=S+F+P$ ;  $j$  ——对立度系数, 取值一般为-1;  $i$  ——差异度系数,  $i \in [-1, 1]$ , 它是宏观与微观两个层次相互结合的参量, 是集对分析的关键。

可见, SPA 的基础是构建集对, 关键是建立和计算联系度。

秩次集对分析 (rank and set pair analysis, RSPA) 是 SPA 方法的发展, 它主要改进了 SPA 确定联系度的方法, 不再使用主观性很强的均值标准差法、均值离差法等传统方法, 而是用能够反映时间序列变化趋势且更客观的秩次法确定联系度。

秩次就是相对位次的大小, 如集合  $C=(4, 10, 2, 6, 15, 9)$ , 那么与之相对应的秩次集合为  $C'=(2, 5, 1, 3, 6, 4)$ 。所以 RSPA 是对秩次集合构成的集对进行分析从而建立联系度的, 因此在 RSPA 之前先要对原始集合进行秩次变换。

## 2 基于 EEMD 去噪和改进 RSPA 的风电功率预测模型

风电功率时间序列具有非平稳性、不确定性和随机性, 因此很难掌握其变化规律。而掌握风电功率的变化规律恰恰是风电功率预测方法的本质。目前大部分预测方法直接利用采集的数据进行仿真, 而忽略了风电功率数据在采集过程中由于受到各种因素的干扰而产生的噪声对预测方法的影响。受到噪声的影响, 预测方法在寻找风电功率时间序列的变化规律时会产生偏差, 从而导致预测准确度不高。因此, 在预测之前对风电功率数据进行去噪是十分必要的。本文利用 EEMD 方法对风电功率数据进行去噪处理。

### 2.1 EEMD 去噪

EEMD 可从含有噪声的信号中提取弱周期性、准周期性的有用成分。根据 EEMD 的方法原理, EEMD 会把风电功率时间序列按不同频带分解成有限个 IMF 分量和一个趋势分量。通常情况下, 高频分量所包含的有用信息较少, 一般为噪声分量。所以本文通过计算频率较高的 IMF 分量与原始信号之间的相关系数来确定噪声项, 频率较低

的 IMF 分量和趋势分量作为非噪声项保留, 其原理如下:

计算每个 IMF 分量的极大值点个数, 将极大值点个数超过某特定数值的 IMF 分量视为高频 IMF 分量; 然后计算这些高频分量与原始信号之间的相关系数; 设定一个阈值, 相关系数低于阈值的 IMF 分量视为噪声分量, 然后把去噪后剩下的 IMF 分量与趋势分量进行重构, 得到消噪功率序列。

### 2.2 改进秩次集对分析

分析风电功率集对的秩次能够很好地掌握风电功率序列的变化趋势, 但变化趋势相同的序列其幅值可能相差很大, 如图 1 所示。




图1 秩次相同幅值不同的两风电功率时序图

Fig. 1 Two wind power time series with the same rank but different amplitude

图中序列 1 为目标序列, 序列 2 为按秩次法找到的集对联系度最大的相似序列, 按集对分析预测的思想, 将序列 2 的后续值 135.4 kW 作为序列 1 的预测值, 而 135.4 kW 与实际值 413.5 kW 偏差很大, 导致预测准确度大大下降。因此, 考虑风电功率序列的幅值十分必要。本文将构成集对的两个序列的平均值之差的绝对值, 即  $h = |\bar{A} - \bar{B}|$  作为建立联系度的另一个重要因素, 原则是  $h$  越小, 两序列越相似, 则改进联系度为:

$$\mu'(A, B) = 0.5 \left( \frac{S}{N} + \frac{F}{N}i + \frac{P}{N}j \right) + 0.5 \left( 1 - \frac{h}{\text{Max}(h)} \right) \quad (6)$$

其中,  $\text{Max}(h)$  ——所有  $h$  中的最大值, 用  $h$  除以  $\text{Max}(h)$  是归一化处理, 使得后一项与前一项保持量纲相同。这样建立的联系度能够有效地避免在寻

找相似集合时出现图 1 所示的错误判断。

### 2.3 实时预测

本文采用改进秩次集对分析方法对消噪序列进行预测。基于集对分析的预测思想是一种相似预测,其具体的过程如下:

设时间序列  $x_1, x_2, \dots, x_n$ , 且  $x_i$  和  $m$  个相邻的历史值  $x_{i-1}, x_{i-2}, \dots, x_{i-m}$  有关。

首先,滑动生成集合  $B_i = (x_i, x_{i+1}, \dots, x_{i+m-1})$   $i = 1, 2, \dots, n-m$ , 并保留每个集合的后续值  $x_{i+m}$ 。其次将集合  $B_{n+1} = (x_{n-m+1}, x_{n-m+2}, \dots, x_{n-1}, x_n)$  与  $B_i$  分别建立秩次集对,再进行改进秩次集对分析,建立联系度。最后根据联系度最大原则找出与  $B_{n+1}$  最相似的集合  $B_k$ , 将  $B_k$  的后续值作为  $x_{n+1}$  的预测值。

由于风电功率时间序列中含有一定的日周期性分量<sup>[15]</sup>,且经 EEMD 分解后的 IMF 分量具有一定的周期性,而秩次集对分析能够反映时间序列的变化趋势的相似性。因此,针对实时预测这种短期预测,采用改进秩次集对分析进行预测,有望提高预测准确度。

### 2.4 基于EEMD去噪和改进RSPA的风电功率预测模型(EEMD&RPSA)

实时预测是一个多步预测的过程。本文采用滚动多步预测的方式进行预测。

模型建立过程如下:

- 1) 将原始风电功率序列  $X(t)$  经 EEMD 分解后得到有限个 IMF 分量和一个趋势分量;
- 2) 计算得到各个 IMF 分量的极大值点的数量;
- 3) 分析极大值点个数  $m$  超过 100(高频分量)的 IMF 分量与原始序列  $X$  之间的相关系数  $s$ , 将相关系数  $s$  小于 0.25 的序列视为噪声序列予以剔除;

4) 将剩下的 IMF 分量和趋势分量进行重构(叠加)作为去噪后的序列;

5) 利用改进 RSPA 对消噪后的序列进行实时预测,得到预测值  $x$ ;

6) 将得到的预测值作为实际值放入  $X(t)$  中,取  $X(2)$  到  $X(t+1)$  作为新的原始序列  $X'(t)$ , 重复执行 1)→6)步,直到达到预测步数为止。

建立的多步预测模型流程图如图 2 所示。

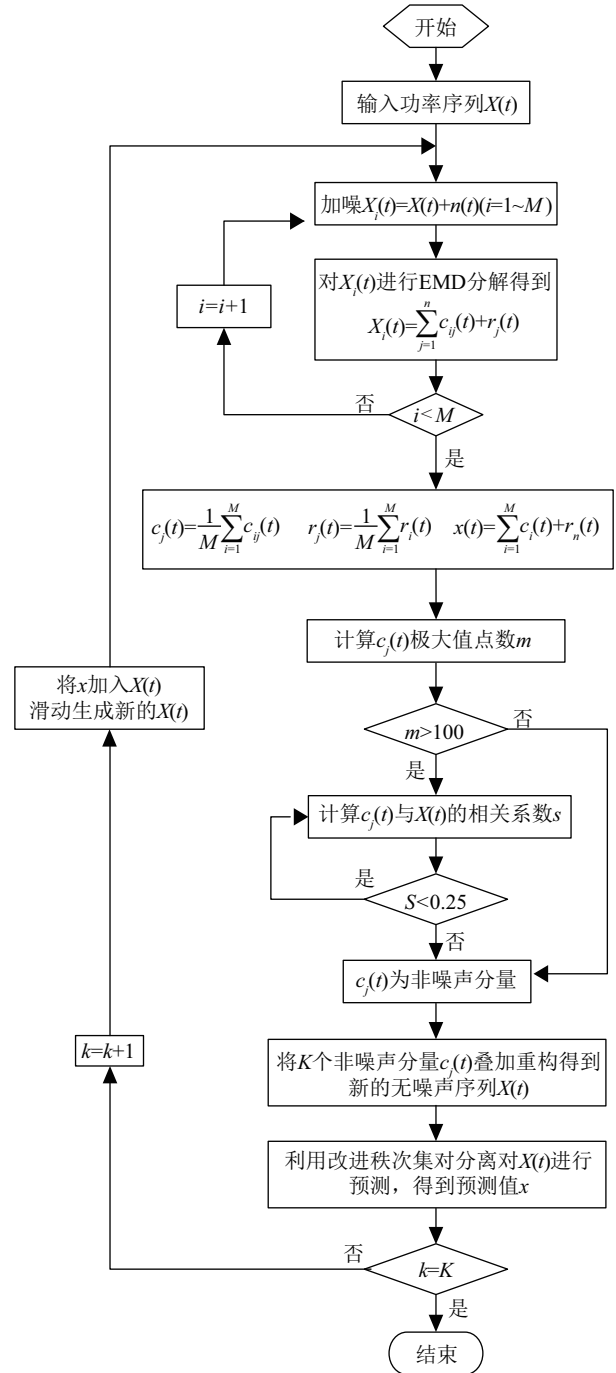


图2 建模流程图

Fig. 2 The modeling flow diagram

## 3 仿真实验与结果分析

### 3.1 数据来源

以东北某省的 3 个风电场整场输出的风电功率实测数据为研究对象。采样时间间隔为 15 min, 时间跨度为 2015 年 5 月 1 日到 2015 年 6 月 1 日



共 31 天。3 个风电场的装机容量如表 1 所示。

表 1 风电场装机容量表

Table 1 The installed capacity of wind farms

风电场	A	B	C
装机容量/MW	49.5	99	320

将风电场 B 的仿真结果作为展示对象,为了验证本文所提出的预测方法的普遍性,用该方法对多个装机容量不同的风电场进行仿真实验。

### 3.2 评价指标

本文采用国家能源局文件风电场功率预测预报管理暂行办法中的评价指标:日平均预测计划曲线准确率  $r_1$ 、日平均预测计划曲线合格率  $r_2$ 、全天预测结果均方根误差  $r_3$  来对预测的结果进行衡量。出各个指标公式如下:

日平均预测计划曲线准确率  $r_1$ :

$$r_{1i} = \left[ 1 - \sqrt{\frac{1}{16} \sum_{k=1}^{16} \left( \frac{P_{Mi}^k - P_{Pi}^k}{Cap} \right)^2} \right] \times 100\% \quad (7)$$

$$r_1 = \frac{1}{96} \sum_{i=1}^{96} r_{1i} \quad (8)$$

日平均预测计划曲线合格率  $r_2$ :

$$r_{2i} = \frac{1}{16} \sum_{k=1}^{16} B_i^k \times 100\% \quad (9)$$

$$\left( 1 - \frac{|P_{Mi}^k - P_{Pi}^k|}{Cap} \right) \times 100\% \geq 85\%, B_i^k = 1 \quad (10)$$

$$\left( 1 - \frac{|P_{Mi}^k - P_{Pi}^k|}{Cap} \right) \times 100\% < 85\%, B_i^k = 0 \quad (11)$$

$$r_2 = \frac{1}{96} \sum_{i=1}^{96} r_{2i} \quad (12)$$

全天预测结果均方根误差  $r_3$ :

$$r_3 = \sqrt{\frac{1}{96 \times 16} \sum_{i=1}^{96} \sum_{k=1}^{16} \left( \frac{P_{Mi}^k - P_{Pi}^k}{Cap} \right)^2} \times 100\% \quad (13)$$

式中,  $r_{2i}$  ——第  $i$  次实时预测的合格率;  $r_{1i}$  ——第  $i$  次实时预测的准确率;  $P_{Mi}^k$  ——第  $i$  次实时预测中第  $k$  时刻的实际风电功率;  $P_{Pi}^k$  ——第  $i$  次实时预测中第  $k$  时刻的预测风电功率;  $Cap$  ——风电场装机容量。

### 3.3 仿真实验

以风电场 B 为例,风电场 B 整场风电功率时序图如图 3 所示。




图 3 风电场 B 整场风电功率时序图

Fig. 3 Sequence diagram of wind power for the wind farm B generation

将建模域长度设为 2000,即用预测起始点前 2000 个点进行建模,预测该点及以后的 16 个点(实时预测)。以预测起始点为 2540 为例,预测 2541~2556 共 16 个点的风电功率。

图 4 为建模域 2000 个点(541~2540)的原始风电功率序列。




图 4 建模域原始风电功率序列

Fig. 4 The original wind power sequence of modeling domains

用 EEMD 对该建模域进行分解后,得到 9 个 IMF 分量( $C_1 \sim C_9$ )和一个剩余分量  $r_{10}$ ,如图 5 所示。

由图 5 可知,经 EEMD 分解后得到的 IMF 低频分量比原始风电功率序列平稳得多,而且具有一定周期性。

表 2 给出了每个 IMF 分量的极大值点数  $m$ 。

表 2 各分量极大值点个数表

Table 2 The number of maximum points for  $C_1 \sim C_9$  and  $r_{10}$

分量	$C_1$	$C_2$	$C_3$	$C_4$	$C_5$	$C_6$	$C_7$	$C_8$	$C_9$	$r_{10}$
$m$	653	297	138	63	26	14	8	2	1	0




图5 建模域的EEMD分解结果

Fig. 5 The EEMD result of modeling domains

表4 不同模型的实时预测结果(%)

Table 4 The results of real-time prediction with different models(%)


预测日	EEMD&RSPA			RSPA			AR			持续法		
	$r_1$	$r_2$	$r_3$	$r_1$	$r_2$	$r_3$	$r_1$	$r_2$	$r_3$	$r_1$	$r_2$	$r_3$
10	88.94	87.50	11.06	83.83	68.75	16.17	76.99	75.62	18.21	76.42	67.87	21.33
11	85.82	62.50	14.18	82.58	43.75	17.42	79.46	43.72	21.35	77.95	43.65	22.03
12	88.79	81.25	11.21	87.13	68.75	12.78	80.69	65.98	23.52	79.71	61.35	28.54
13	89.52	83.75	10.48	78.50	65.00	21.50	76.31	64.70	33.95	63.54	49.17	41.79
平均	88.27	78.75	11.73	83.01	61.56	16.97	78.36	68.77	24.25	72.64	55.51	28.42

根据规定,极大值点个数  $m > 100$  的 IMF 分量视为高频分量。则  $C_1 \sim C_3$  为高频分量,计算它们与原始风电功率序列的相关系数,结果如表 3 所示。

表3  $C_1 \sim C_3$  相关系数表Table 3 The correlation coefficient of  $C_1 \sim C_3$ 

IMF 分量	$C_1$	$C_2$	$C_3$
与 $X$ 的相关系数 $s$	0.1552	0.2167	0.2824

从表中可知,  $C_1$  与  $C_2$  与  $X(t)$  的相关系数小于 0.25, 所以将其视为噪声分量予以剔除。将剩下的  $C_3 \sim C_9$  分量和  $r_{10}$  分量叠加后重构成去噪序列  $X'(t)$ 。图 6 给出了  $X(t)$  与  $X'(t)$  的部分数据对比图。

图6  $X(t)$  与  $X'(t)$  的部分数据对比图Fig. 6 The partial sequence of  $X(t)$  and  $X'(t)$ 

从图 6 中可看出,消噪后的风电功率序列更加平滑,而且能够很好地把握风电功率的变化趋势。

最后利用改进 RSPA 方法对消噪后的序列  $X'(t)$  进行预测。为了验证本文方法(EEMD & RSPA)的优越性,将 EEMD & RSPA 的结果与不进行消噪的秩次集对分析预测法(RSPA)、使用较广泛的 AR 模型预测法以及较简单的持续预测法的预测结果进行比较,共得到 4 个预测日的结果,如表 4 所示。

从表 4 中可看出,除了预测日 10 日的合格率外,秩次集对分析法(RSPA)的预测结果均优于 AR 模型法和持续法,证明了秩次集对分析在风电这种具有非平稳性、随机性和不确定性对象上应用的可行性,同时也说明了秩次法能较好地把握风电功率序列的变化趋势。持续法的预测效果最差,这是由于持续法将当前值作为预测值,只把握了当前值,未掌握风电功率序列变化的规律造成的,所以,持续法预测更适用于单步预测。

本文所提出的 EEMD & RSPA 方法的平均准确率  $r_1$  比 RSPA、AR 和持续法模型分别提高了 5.26%、9.91%以及 15.63%;合格率  $r_2$  分别提高了 17.19%、9.98%以及 23.24%;而全天预测结果均方根误差  $r_3$  分别降低了 5.22%、12.50%以及 16.67%,普遍优于其他 3 种方法。这表明了噪声对于预测方法准确把握风电功率序列的变化趋势具有较大影响。在预测前将噪声滤除对于提高预测准确率十分重要。

图 7 给出了 4 种方法在某个点实时预测的预测效果图。从图中也可看出,本文所提出的方法优

于其他 3 种方法。




图 7 各种预测方法预测效果图  
Fig. 7 The real-time prediction pattern of all method

为了验证本文提出的 EEMD & RSPA 方法的普适性,利用 EEMD & RSPA、RSPA、AR 以及持续法模型分别对风电场 A、风电场 B 和风电场 C 的风电功率实测数据进行预测,得到的结果如表 5 所示。从表 5 可知,本文提出的 EEMD & RSPA 模型对不同装机容量风电场风电功率预测的结果仍是最优的,证明了 EEMD & RSPA 模型的普适性。

表 5 不同装机容量风电场的实时预测结果(%)

Table 5 The real-time prediction results for different wind farms with different installed capacity (%)

预测日	风电场 A			风电场 B			风电场 C		
	$r_1$	$r_2$	$r_3$	$r_1$	$r_2$	$r_3$	$r_1$	$r_2$	$r_3$
EEMD&RSPA	88.57	83.17	12.37	89.58	87.09	11.75	90.56	85.96	12.40
RSPA	84.97	66.86	15.64	87.56	77.86	14.02	88.06	79.10	13.72
AR	80.23	76.93	17.17	85.91	77.20	17.37	86.18	78.86	15.80
持续法	78.85	63.92	21.42	79.62	67.87	20.54	80.44	70.37	16.89

## 4 结 论

针对大多数预测方法在对风电功率进行预测时未考虑噪声,从而影响预测方法把握风电功率序列变化趋势的问题,本文提出一种基于 EEMD 消噪和改进秩次集对分析的风电功率实时预测方法。利用 EEMD 将风电功率序列进行更准确的分解,将高频分量噪声滤除,使得到的消噪序列更加平稳且变化趋势更加清晰。同时对秩次集对分析进行改进,考虑了风电功率序列的幅值对联系度的影响,建立更适于风电对象的新的联系度,从而提高秩次集对分析对风电功率序列变化趋势的把握能力。

将本文提出的 EEMD&RSPA 与 RSPA、AR 以

及持续法的预测性能进行比较,验证 EEMD&RSPA 的优越性。并利用 EEMD&RSPA 对 3 个不同装机容量的风电场的风电功率实测数据进行预测,验证了 EEMD&RSPA 的普适性。

## [参考文献]

- [1] Wu Z, Huang N E. Ensemble empirical mode decomposition: A noise-assisted data analysis method [J]. Advances in Adaptive Data Analysis, 2009, 1(1), 1—41.
- [2] Jung J, Broadwater R P. Current status and future advances for wind speed and power forecasting[J]. Renewable and Sustainable Energy Reviews, 2014, 31:

- 762—777.
- [3] 李国庆, 张 钰, 张明江, 等. 基于MRMR的集合经验模态分解和支持向量机的风电功率实时预测[J]. 东北电力大学学报, 2017, 37(2): 39—44.
- [3] Li Guoqing, Zhang Yu, Zhang Mingjiang, et al. The wind power real-time prediction based on the EEMD and SVM of the MRAR [J]. Journal of Northeast Electric Power University, 2017, 37(2): 39—44.
- [4] 赵永宁, 叶 林. 区域风电场短期风电功率预测的最大相关-最小冗余数值天气预报特征选取策略[J]. 中国电机工程学报, 2015, 35(23): 5985—5994.
- [4] Zhao Yongning, Ye Lin. A numerical weather prediction feature selection approach based on minimal-redundancy- maximal- relevance strategy for short-term regional wind power prediction [J]. Proceedings of the CSEE, 2015, 35(23): 5985—5994.
- [5] 王 勃, 冯双磊, 刘 纯. 基于天气分型的风电功率预测方法[J]. 电网技术, 2014, 38(1): 93—98.
- [5] Wang Bo, Feng Shuanglei, Liu Chun. Study on weather typing based wind power prediction [J]. Power System Technology, 2014, 38(1): 93—98.
- [6] 李 丽, 叶 林. 基于改进持续法的短期风电功率预测[J]. 农业工程学报, 2010, 26(12): 182—187.
- [6] Li Li, Ye Lin. Short-term wind power forecasting based on an improved persistence approach [J]. Transactions of the CSAE, 2010, 26(12): 182—187.
- [7] 冬 雷, 王丽婕, 郝 颖, 等. 基于自回归滑动平均模型的风力发电容量预测[J]. 太阳能学报, 2011, 32(5): 617—622.
- [7] Dong Lei, Wang Lijie, Hao Ying, et al. Prediction of wind power generation based on autoregressive moving average model [J]. Acta Energiæ Solaris Sinica, 2011, 32(5): 617—622.
- [8] 周松林, 茆美琴, 苏建徽. 基于主成分分析与人工神经网络的风电功率预测[J]. 电网技术, 2011, 35(9): 128—132.
- [8] Zhou Songlin, Mao Meiqin, Su Jianhui. Prediction of wind power based on principal component analysis and artificial neural network [J]. Power System Technology, 2011, 35(9): 128—132.
- [9] 杨 茂, 黄宾阳, 江 博, 等. 基于卡尔曼滤波和支持向量机的风电功率实时预测研究[J]. 东北电力大学学报, 2017, 37(2): 45—51.
- [9] Yang Mao, Huang Binyang, Jiang Bo, et al. Real-time prediction for wind power based on Kalman filter and support vector machines [J]. Journal of Northeast Electric Power University, 2017, 37(2): 45—51.
- [10] 刘红柳, 杨 茂. 基于小波变换和支持向量机的风电功率爬坡事件识别与预测[J]. 东北电力大学学报, 2016, 36(6): 30—35.
- [10] Liu Hongliu, Yang Mao. An approach for wind power climbing event identification and prediction based on wavelet and SVM [J]. Journal of Northeast Electric Power University, 2016, 36(6): 30—35.
- [11] 杨 茂, 陈新鑫, 张 强, 等. 基于支持向量机的短期风速预测研究综述[J]. 东北电力大学学报, 2017, 37(4): 1—7.
- [11] Yang Mao, Chen Xinxin, Zhang Qiang, et al. A review of short-term wind speed prediction based on support vector machine [J]. Journal of Northeast Electric Power University, 2017, 37(2): 39—44.
- [12] 国家能源局. 风电厂功率预测预报管理暂行办法[S]. 北京: 国家能源局, 2011.
- [12] The National Energy Board. The notification of wind power forecasting management interim measures [S]. Beijing: Published by the National Energy Board, 2011.
- [13] 万 红, 管 磊, 刘新玉. 锋电位检测信号的EEMD去噪方法研究[J]. 系统仿真学报, 2015, 27(1): 118—124.
- [13] Wang Hong, Guan Lei, Liu Xinyu. EEMD denoising method for neuronal spike signals [J]. Journal of System Simulation, 2015, 27(1): 118—124.
- [14] 汪明武. 集对分析耦合方法与应用[M]. 北京: 科学出版社, 2014.
- [14] Wang Mingwu. Set pair analysis based coupling methods and applications [M]. Beijing: Science Press, 2014.
- [15] 杨 茂, 王 东, 严干贵, 等. 风电功率波动特性中的周期性研究[J]. 太阳能学报, 2013, 33(11): 2020—2026.
- [15] Yang Mao, Wang Dong, Yan Gangui, et al. Study on periodicity for wind power fluctuations characteristics [J]. Acta Energiæ Solaris Sinica, 2013, 33(11): 2020—2026.



## REAL-TIME PREDICTION FOR WIND POWER BASED ON EEMD DENOISING AND THEORY OF SPA

Yang Mao<sup>1</sup>, Chen Yulin<sup>1</sup>, Wei Zhicheng<sup>2</sup>

(1. School of Electronic Engineering, Northeast Electric Power University, Jilin 132012, China;

2. State Grid Anhui Maintenance Company, Hefei 230061, China)

**Abstract:** The nature of wind power prediction is to grasp the change law of wind power accurately. However, most forecasting methods at present have ignored the impact of noise on grasping the variation of wind power. Therefore, this paper presents a method of real-time prediction for wind power based on EEMD denoising and improved rank and set pair. At first, EEMD is used to decompose the wind power time series, and the wind power sequence is decomposed into finite number of IMF component and a trend component. Then, the high frequency IMF component who have less correlation with the original sequence is regarded as the noise, the rest of non-noise IMF component and trend component is reconstructed as new sequence who hasn't noise. Finally, the rank and set pair prediction model is used to predict the new sequence. When we establish the rank and set pair prediction model, the influence of amplitude of wind power for the connection degree building is considered, so the connection degree built is improved. The data of three different wind farms with different installed capacity is used to implement simulation experiment, the results show that the proposed approach has superior prediction performance and good universality.

**Keywords:** wind power; real-time prediction; EEMD de-noising; rank and set pair analysis; connection degree